


# Mesterséges Intelligencia

## Neurális hálók

### Biológiai és mesterséges neuron



A kép két fontos koncepciót ábrázol: a **biológiai neuront** és annak mesterséges intelligencia modellekben használt analógiáját. A *biológiai neuron* az emberi agy alapvető építőeleme, amely információkat dolgoz fel és továbbít más neuronok felé. A neuron **dendritekkel** rendelkezik, amelyek a környező neuronoktól érkező jeleket fogadják. Ezeket a jeleket a sejttest (amelyben a **mag** található) dolgozza fel, majd továbbküldi az **axonon** keresztül. Az axon végén található axonvégződés **szinapszisokon** keresztül kapcsolódnak más neuronokhoz, így biztosítva az információáramlást.

A **mesterséges neuron** e biológiai modell alapján működik, leegyszerűsítve annak alapvető mechanizmusait. A mesterséges neuron bemeneteket fogad, amelyeket matematikailag súlyoz (ezzel vezérli a bemenet fontosságát), majd összegez. Az így kapott értéken egy **aktivációs függvényt** futtat, amely meghatározza, hogy a neuron "tüzel-e", azaz továbbküldi-e a jelet. Az aktivációs függvény eredménye képezi a neuron kimenetét, amelyet továbbít a hálózat következő rétegeinek.

### Neurális háló

Az alábbi kép egy mesterséges neurális hálózat egyszerű modelljét ábrázolja.




A hálózat bemeneti réteggel indul, amely a zöld színű  $x_1$  és  $x_2$  elemeket tartalmazza. Ezek a bemeneti változók képviselik azokat az adatokat, amelyeket a modell feldolgoz. A bemeneteket súlyokkal és eltolásokkal kombinálják, majd átadják a rejtett rétegek neuronjaiba, amelyeket a kék színű  $z_1$ ,  $z_2$  és  $z_3$  jelöl.

A **rejtett réteg(ek)**ben minden neuron kiszámítja a saját kimenetét egy **aktivációs függvény** segítségével, amely a bemeneti jelek összegét alakítja át (nemlineáris módon). Ezek a kimenetek aztán tovább haladnak a következő rétegekbe, míg végül eléri a kimeneti réteget, amelyet itt az  **$y_{pred}$**  narancssárga elem jelöl.

Az  **$y_{pred}$**  a modell végső előrejelzése, egy számérték, amely például egy *osztályozási* vagy *regressziós* (közelítési) probléma megoldásaként jelenik meg.

Ez az ábra segíthet megérteni a neurális hálózatok alapvető működési elvét: a bemenetek fokozatos átalakulását a különböző rétegeken keresztül, amelyek végül egy adott kimeneti értékhez vezetnek. Ezt a folyamatot a gépi tanulás során finoman hangolják (optimalizálják), például *visszaterjesztés* (backpropagation) és *gradienscsökkentés* (gradient descent) segítségével, hogy a modell pontos előrejelzéseket tudjon adni.



## Neurális háló, mint osztályozó - Generatív hálók

Az alábbi link a számok felismerését teszi láthatóvá: [https://adamharley.com/nn\\_vis/](https://adamharley.com/nn_vis/)

Az alábbi linken bemutatjuk, hogyan működik az osztályozás? Autoencoder és generatív modellek.

<http://showroom.iit.uni-miskolc.hu/gans>

## Generatív nyelvi modellek

A generatív nyelvi modellek az emberi nyelv megértésére és szöveg generálására irányuló kutatások központi elemei. Ezek a modellek arra képesek, hogy a bemenetként adott szöveg alapján értelmes és összefüggő szöveget állítsanak elő. Az alábbiakban bemutatjuk a generatív nyelvi modellek fejlődését, amely a GPT (Generative Pre-trained Transformer) családdhoz vezetett.

### 1.) Hagyományos megközelítések (1950-2000-es évek)

- **Statikus modellek:** A nyelv feldolgozásához egyszerű szabályalapú rendszereket (pl. grammatikai szabályok) használtak.
- **Markov-láncok:** Egy szó valószínűségét csak az előző szavak határozták meg, így a kontextus figyelembevétele korlátozott volt.

Hiányosságok: A modellek nem tudták kezelni a hosszabb távú összefüggéseket. Az adatok mennyisége és feldolgozási kapacitás limitált volt.

### 2.) Neurális hálózatok alkalmazása (2010 körül)

**Word Embeddingek: Word2Vec (2013):** Az egyes szavak vektortérbeli reprezentációját hozta létre, amely tükrözi a szemantikai kapcsolataikat (king - man + woman  $\approx$  queen).

**Recurrent Neural Networks (RNNs)** Az RNN-ek a szekvenciális adatok feldolgozására készültek. Például egy szó vektora a korábbi szavak kontextusán alapult.

Hiányosságok: Lassúak és nehezen tanulhatók nagy mennyiségű adat esetén. Nem tudtak hatékonyan kezelni nagyon hosszú szövegeket.

### 3.) Attention Mechanizmus és Transformer (2017)

**Attention Mechanizmus:** A figyelem-alapú modellek a bemenetek bizonyos részeire nagyobb súlyt helyeztek, ezáltal hatékonyabbá tették az összefüggések felismerését.

**Transformer Architektúra (2017):** Az „Attention is All You Need” című cikkben a Google kutatói bevezették a Transformer modellt. Kulcseleme az önfigyelem (self-attention), amely lehetővé tette, hogy a modell párhuzamosan dolgozza fel az adatokat, szemben az RNN-ek szekvenciális feldolgozásával.

Előnyök: Jobb skálázódás nagyobb adathalmazokon. Hatékony hosszú szövegek feldolgozása.

### 4. Generatív Pre-Trained Modellek (GPT család)

**GPT-1 (2018):** Az első modell, amely a Transformer architektúrát alkalmazta nagyméretű nyelvi korpuszokon.

**GPT-2 (2019):** Nagyobb és erősebb modell, amely képes volt teljes cikket generálni emberi beavatkozás nélkül.

**GPT-3 (2022):** Egy óriási ugrás: 175 milliárd paraméter.

**GPT-4 (2023):** Még fejlettebb modell, több multimodális képességgel (pl. szöveg és kép feldolgozása).

**GPT-5 (2025):** Jelenlegi legfejlettebb modell, érvelés, gondolkodás, eszközök használata.

Számlafeldolgozó minta bemutatása.

### Neurális hálózatok, felmerülő kérdések

1. Magyarázható-e a működése? (a súlyok alapján érthető-e a döntés?)
2. Van-e itt intelligencia egyáltalán?

From: <https://edu.iit.uni-miskolc.hu/> - Institute of Information Science - University of Miskolc

Permanent link: [https://edu.iit.uni-miskolc.hu/digitalis\\_techologiak\\_ikt\\_techologiak:mesterseges\\_intelligencia?rev=1778183008](https://edu.iit.uni-miskolc.hu/digitalis_techologiak_ikt_techologiak:mesterseges_intelligencia?rev=1778183008)

Last update: 2026/05/07 19:43

